

文章编号:1005-3085(2010)04-0637-06

## 一类新的记忆梯度法及其收敛性\*

汤京永<sup>1,2</sup>, 董 丽<sup>1</sup>

(1- 信阳师范学院数学与信息科学学院, 信阳 464000; 2- 上海交通大学数学系, 上海 200240)

**摘 要:** 本文着重研究求解无约束优化问题的记忆梯度法, 利用当前和前面一步迭代点的信息产生下降方向, 采用 Armijo 线性搜索确定步长, 得到了一类新的无约束优化算法。新算法在较弱的条件下具有全局收敛性和线性收敛速率, 并且不用计算和存储矩阵, 适于求解大规模优化问题。数值试验表明算法是有效的。

**关键词:** 无约束优化; 记忆梯度法; 全局收敛性; 线性收敛速率

**分类号:** AMS(2000) 90C30; 65K05; 49M37

**中图分类号:** O221.2

**文献标识码:** A

### 1 引言

考虑无约束优化问题

$$\min f(x), \quad x \in R^n, \quad (1)$$

其中  $R^n$  是  $n$  维欧氏空间,  $f(x): R^n \rightarrow R$  为连续可微函数,  $g(x)$  为其梯度。求解问题(1)的算法主要是迭代法, 基本结构为

$$x_{k+1} = x_k + \alpha_k d_k,$$

其中  $d_k$  为搜索方向,  $\alpha_k$  为步长参数。对  $\alpha_k$  和  $d_k$  的不同选择就构成了不同的迭代法<sup>[1]</sup>。在本文中, 若  $x_k$  为当前迭代点, 则简记  $g(x_k)$  为  $g_k$ ,  $f(x_k)$  为  $f_k$ ,  $f(x^*)$  为  $f^*$ 。

共轭梯度法在每步迭代中不需计算和存储矩阵, 是求解大型无约束优化问题的有效算法之一。记忆梯度法类似于共轭梯度法, 也是求解大规模优化问题的有效方法, 并且与共轭梯度法相比, 记忆梯度法增加了参数选择的自由度, 更有利于构造稳定的快速收敛算法<sup>[2-8]</sup>。

本文提出一类新的求解无约束优化问题的记忆梯度法, 算法利用当前和前面一步迭代点的信息以及 Armijo 步长规则产生新的迭代点, 结构简单, 不用计算和存储矩阵, 适于求解大规模优化问题。与文献 [5-8] 中的算法相比, 新算法有下面三个优点: 一是假设条件较弱, 扩大了算法求解问题的范围; 二是在较弱的条件下具有全局收敛性和线性收敛速率; 三是具有较好的数值试验结果。

### 2 记忆梯度法及其性质

本文作如下假设:

(H<sub>1</sub>) 目标函数  $f(x)$  在水平集  $L_0 = \{x \in R^n \mid f(x) \leq f(x_1)\}$  上有下界。

(H<sub>2</sub>) 梯度函数  $g(x)$  在包含  $L_0$  的开凸集  $B$  上一致连续。

收稿日期: 2008-08-15. 作者简介: 汤京永(1979年6月生), 男, 博士, 讲师. 研究方向: 优化理论与算法.

\*基金项目: 国家自然科学基金(10571109); 信阳师范学院青年基金(200946; 200947).

**算法 1** 取  $\eta \in (\frac{1}{2}, 1)$ ,  $\rho \in (0, 1)$ ,  $\beta \in (0, 1)$ ,  $x_1 \in R^n$ . 令  $k := 1$ .

**步骤 1** 若  $\|g_k\| = 0$ , 则停止迭代; 否则, 转步骤 2.

**步骤 2** 计算  $d_k$ , 使其满足

$$d_k = \begin{cases} -g_k, & k = 1, \\ -g_k + \beta_k \delta_{k-1}, & k \geq 2, \end{cases} \quad (2)$$

其中  $\delta_{k-1} = d_{k-1} - g_{k-1}$ , 而

$$\beta_k = \begin{cases} 0, & \text{若 } d_{k-1} = g_{k-1}, \\ \frac{\eta \|g_k\|}{\|\delta_{k-1}\|}, & \text{若 } d_{k-1} \neq g_{k-1}. \end{cases} \quad (3)$$

**步骤 3**  $x_{k+1} = x_k + \alpha_k d_k$ , 其中  $\alpha_k$  由 Armijo 搜索准则确定, 即要求  $\alpha_k$  为  $\{1, \beta, \beta^2, \dots\}$  中满足下式的最大者

$$f(x_k) - f(x_k + \alpha d_k) \geq -\rho \alpha g_k^T d_k. \quad (4)$$

**步骤 4** 令  $k := k + 1$ , 转步骤 1.

**引理 1** 对任意的  $k \geq 1$ , 有  $-g_k^T d_k \geq (1 - \eta) \|g_k\|^2$ .

**注** 由引理 1 及 (4) 式可知  $\{f_k\}$  单调不增且  $x_k \in L_0$ .

**引理 2** 对任意的  $k \geq 1$ , 有  $\|d_k\| \leq (1 + \eta) \|g_k\|$ .

### 3 算法的全局收敛性

**定理 1** 假设  $(H_1)$  和  $(H_2)$  成立, 则算法 1 或有限步终止于问题 (1) 的稳定点; 或产生无穷点列  $\{x_k\}$ , 其任意聚点都是问题 (1) 的稳定点.

**证明** 若  $g(x_k) = 0$ , 则  $x_k$  为稳定点. 假设算法 1 产生无穷点列  $\{x_k\}$ ,  $x^*$  为其任意聚点, 则存在子列  $\{x_k : k \in K\}$ ,  $K \subset \{1, 2, \dots\}$ , 使  $\lim_{k \in K, k \rightarrow \infty} x_k = x^*$ . 下面分两种情况讨论.

**情况 1**  $\inf_{k \in K} \alpha_k > 0$ . 由 (4) 式和引理 1 可知

$$f_k - f_{k+1} \geq -\rho \alpha_k g_k^T d_k \geq \rho(1 - \eta) \alpha_k \|g_k\|^2. \quad (5)$$

因为  $\{f_k\}$  单调不增有下界, 故  $\{f_k\}$  有极限. 由 (5) 式知  $\lim_{k \rightarrow \infty} \alpha_k \|g_k\|^2 = 0$ , 故

$$\lim_{k \in K, k \rightarrow \infty} \alpha_k \|g_k\|^2 = 0,$$

进而由  $\inf_{k \in K} \alpha_k > 0$  可知  $\lim_{k \in K, k \rightarrow \infty} \|g_k\|^2 = 0$ , 即

$$\lim_{k \in K, k \rightarrow \infty} \|g_k\| = 0.$$

因为  $\lim_{k \in K, k \rightarrow \infty} x_k = x^*$ , 且  $g(x)$  连续, 所以  $g(x^*) = 0$ , 故知  $x^*$  是问题 (1) 的稳定点.

**情况 2**  $\inf_{k \in K} \alpha_k = 0$ . 由  $\inf_{k \in K} \alpha_k = 0$  知存在子列  $N \subset K$ , 使

$$\lim_{k \in N, k \rightarrow \infty} \alpha_k = 0,$$

故知存在  $K' > 0$ , 当  $k \in N$  且  $k > K'$  时有  $\alpha_k < 1$ , 进而可知  $\alpha_k \beta^{-1} \in \{1, \beta, \beta^2, \dots\}$ . 令  $\alpha = \alpha_k \beta^{-1}$ , 则由 Armijo 搜索准则可得

$$f_k - f(x_k + \alpha_k \beta^{-1} d_k) < -\rho \alpha_k \beta^{-1} g_k^T d_k, \quad k \in N, \quad k > K'. \quad (6)$$

对不等式 (6) 的左边利用中值定理, 则存在  $\theta_k \in (0, 1)$ , 使

$$-\alpha_k \beta^{-1} g(x_k + \theta_k \alpha_k \beta^{-1} d_k)^T d_k < -\rho \alpha_k \beta^{-1} g_k^T d_k, \quad k \in N, \quad k > K',$$

从而知

$$g(x_k + \theta_k \alpha_k \beta^{-1} d_k)^T d_k > \rho g_k^T d_k, \quad k \in N, \quad k > K'. \quad (7)$$

由 Cauchy-Schwartz 不等式, 引理 1 及 (7) 式可知

$$\begin{aligned} \|g(x_k + \theta_k \alpha_k \beta^{-1} d_k) - g_k\| &\geq \frac{(g(x_k + \theta_k \alpha_k \beta^{-1} d_k) - g_k)^T d_k}{\|d_k\|} \\ &\geq \frac{(1-\rho)(1-\eta)\|g_k\|^2}{\|d_k\|}, \quad k \in N, \quad k > K', \end{aligned}$$

从而由引理 2 知

$$\|g(x_k + \theta_k \alpha_k \beta^{-1} d_k) - g_k\| \geq \frac{(1-\rho)(1-\eta)\|g_k\|}{1+\eta}, \quad k \in N, \quad k > K'. \quad (8)$$

因为  $\{x_k : k \in K\}$  有界,  $g(x)$  连续, 故  $\{\|g_k\| : k \in K\}$  有界, 从而由引理 2 可知  $\{\|d_k\| : k \in K\}$  有界. 又因为  $\lim_{k \in N, k \rightarrow \infty} \alpha_k = 0$ , 故

$$\lim_{k \in N, k \rightarrow \infty} \alpha_k \|d_k\| = 0,$$

从而由  $(H_2)$  和 (8) 式知  $\lim_{k \in N, k \rightarrow \infty} \|g_k\| = 0$ . 因为

$$\lim_{k \in N, k \rightarrow \infty} x_k = x^*$$

且  $g(x)$  连续, 所以有  $g(x^*) = 0$ , 故知  $x^*$  是问题 (1) 的稳定点.

## 4 算法的线性收敛速率

假设:

$(H_3)$   $f(x)$  是二次连续可微的一致凸函数.

引理 3<sup>[7]</sup> 若  $(H_3)$  成立, 则  $f(x)$  在  $R^n$  上有唯一的极小点  $x^*$ , 并且存在  $M \geq m > 0$ , 使

$$\frac{m}{2} \|x - x^*\|^2 \leq f(x) - f(x^*) \leq \frac{M}{2} \|x - x^*\|^2, \quad (9)$$

$$m \|x - x^*\| \leq \|g(x)\| \leq M \|x - x^*\|. \quad (10)$$

引理 4<sup>[7]</sup> 若  $(H_3)$  成立, 则  $g(x)$  在水平集  $L_0$  上 Lipschitz 连续, 即存在常数  $L > 0$ , 使

$$\|g(x) - g(y)\| \leq L \|x - y\|, \quad \forall x, y \in L_0.$$

**定理 2** 若  $(H_3)$  成立,  $\{x_k\}$  是由算法 1 产生的无穷点列, 则  $\{x_k\}$  至少线性收敛于  $x^*$ 。

**证明** 若  $\alpha_k = 1$ , 则由 (5) 式可知

$$f_k - f_{k+1} \geq \rho(1 - \eta)\|g_k\|^2. \quad (11)$$

若  $\alpha_k < 1$ , 则由定理 1 的证明过程可知, 存在  $\theta_k \in (0, 1)$ , 使

$$\|g(x_k + \theta_k \alpha_k \beta^{-1} d_k) - g_k\| \geq \frac{(1 - \rho)(1 - \eta)\|g_k\|}{1 + \eta}. \quad (12)$$

由引理 4 及 (12) 可得

$$\alpha_k \beta^{-1} L \|d_k\| \geq \|g(x_k + \theta_k \alpha_k \beta^{-1} d_k) - g_k\| \geq \frac{(1 - \rho)(1 - \eta)\|g_k\|}{1 + \eta},$$

从而由引理 2 知

$$\alpha_k \geq \frac{(1 - \rho)(1 - \eta) \|g_k\|}{L(1 + \eta)\beta^{-1} \|d_k\|} \geq \frac{(1 - \rho)(1 - \eta)}{L(1 + \eta)^2 \beta^{-1}}. \quad (13)$$

由 (5) 式和 (13) 式可得

$$f_k - f_{k+1} \geq \frac{\rho(1 - \rho)(1 - \eta)^2}{L(1 + \eta)^2 \beta^{-1}} \|g_k\|^2. \quad (14)$$

令

$$\omega = \min \left\{ \rho(1 - \eta), \frac{\rho(1 - \rho)(1 - \eta)^2}{L(1 + \eta)^2 \beta^{-1}} \right\},$$

则由  $0 < \rho < 1$ ,  $\frac{1}{2} < \eta < 1$  可知  $0 < \omega < \frac{1}{2}$ 。由 (11) 及 (14) 知  $f_k - f_{k+1} \geq \omega \|g_k\|^2$ 。

余下的证明类似于文献 [7] 中的定理 3, 故略。

## 5 数值试验

为进一步检验算法 1 的实算效果, 我们选取几个算例对本文算法进行数值试验, 并与 Armijo 搜索下的共轭梯度法和最速下降法进行比较。用 IT 表示算法的迭代次数, NA 表示本文提出的新算法, 用 FR, PRP 和 HS 分别表示 FR, PRP 和 HS 共轭梯度法<sup>[6]</sup>, SM 表示最速下降法。参数取值为  $\eta = 0.88$ ,  $\rho = 0.75$ ,  $\beta = 0.5$ 。表中的数字为迭代中的目标函数值, 舍入成小数点后三位有效数字, 一维搜索全部采用 Armijo 搜索。记  $2.381 \times 10^5$  为 2.381(5),  $3.1 \times 10^{-3}$  为 3.100(-3), 其余同。计算结果如下。

**例 1**  $f(x) = (x_1 - x_2)^2 + (x_2 + x_3 - 2)^2 + (x_4 - 1)^2 + (x_5 - 1)^2$ ,  $x_0 = (2, 2, 2, 2, 2)^T$ ,  $x^* = (1, 1, 1, 1, 1)^T$ ,  $f^* = 0$ , 见表 1。

表 1: 例 1 计算结果的比较

IT	NA	FR	PRP	HS	SM
0	6.000(0)	6.000(0)	6.000(0)	6.000(0)	6.000(0)
10	3.100(-3)	2.800(-3)	2.300(-3)	4.200(-3)	1.730(-2)
20	1.965(-8)	3.092(-7)	7.365(-7)	1.252(-6)	1.082(-5)
25	3.291(-11)	9.576(-9)	9.855(-9)	2.171(-8)	1.056(-8)

**例2**  $f(x) = (x_1+10x_2)^4+5(x_3-x_4)^4+(x_2-2x_3)^4+10(x_1-x_4)^4$ ,  $x_0 = (2, 2, -2, -2)^T$ ,  $x^* = (0, 0, 0, 0)^T$ ,  $f^* = 0$ , 见表2。

表2: 例2 计算结果的比较

IT	NA	FR	PRP	HS	SM
0	2.381(5)	2.381(5)	2.381(5)	2.381(5)	2.381(5)
20	1.595(1)	1.362(2)	2.275(1)	2.791(1)	1.298(1)
30	2.860(-2)	1.542(0)	1.719(-1)	3.130(-2)	1.444(-1)
40	1.146(-4)	7.600(-3)	2.300(-3)	8.126(-5)	1.300(-3)

**例3**  $f(x) = (x_1-1)^2+(x_1-x_2)^2+(x_3-1)^2+(x_4-1)^4+(x_5-1)^6$ ,  $x_0 = (2, 2, 2, 2, 2)^T$ ,  $x^* = (1, 1, 1, 1, 1)^T$ ,  $f^* = 0$ , 见表3。

表3: 例3 计算结果的比较

IT	NA	FR	PRP	HS	SM
0	4.000(0)	4.000(0)	4.000(0)	4.000(0)	4.000(0)
10	3.360(-2)	1.200(-1)	1.650(-2)	1.380(-2)	1.090(-2)
20	3.632(-4)	6.662(-4)	8.066(-4)	3.845(-4)	6.656(-4)
30	9.628(-5)	1.434(-4)	2.185(-4)	2.523(-4)	2.810(-4)

**例4**  $f(x) = (1-x_1)^2+(1-x_{10})^2+\sum_{i=1}^9(x_i^2-x_{i+1})^2$ ,  $x_0 = (3, \cdots, 3)^T$ ,  $x^* = (1, \cdots, 1)^T$ ,  $f^* = 0$ , 见表4。

表4: 例4 计算结果的比较

IT	NA	FR	PRP	HS	SM
0	3.320(2)	3.320(2)	3.320(2)	3.320(2)	3.320(2)
20	6.189(-4)	1.020(-2)	4.070(-2)	8.300(-3)	1.050(-2)
30	9.862(-7)	4.226(-4)	2.786(-4)	5.727(-6)	7.075(-5)
50	1.738(-11)	7.345(-8)	2.537(-8)	5.205(-9)	1.042(-8)

**例5 扩展 Beale 函数**

$$f(x) = \sum_{i=1}^{n/2} \left\{ \left[ 1.5 - x_{2i-1}(1 - x_{2i}) \right]^2 + \left[ 2.25 - x_{2i-1}(1 - x_{2i}^2) \right]^2 + \left[ 2.625 - x_{2i-1}(1 - x_{2i}^3) \right]^2 \right\},$$

$$n = 2, 4, \cdots, \quad x_0 = (2, \cdots, 2)^T, \quad x^* = (3, 0.5, \cdots, 3, 0.5)^T, \quad f^* = 0,$$

见表5。

表5: 例5 计算结果的比较 ( $n = 80$ )

IT	NA	FR	PRP	HS	SM
0	1.467(4)	1.467(4)	1.467(4)	1.467(4)	1.467(4)
15	2.152(1)	2.727(1)	1.434(1)	2.293(1)	2.290(1)
20	3.759(0)	1.509(1)	2.206(0)	6.286(0)	3.659(0)
30	3.394(-1)	9.507(-1)	1.834(-1)	1.173(0)	3.075(-1)

参考文献:

- [1] 袁亚湘, 孙文瑜. 最优化理论与方法[M]. 北京: 科学出版社, 1997  
Yuan Y X, Sun W Y. Optimization Theory and Methods[M]. Beijing: Science Press, 1997
- [2] Miele A, Cantrell J W. Study on a memory gradient method for the minimization of functions[J]. JOTA, 1969, 3(6): 459-470
- [3] 李敏, 苏醒, 时贞军. 求解非线性方程组的记忆梯度算法[J]. 工程数学学报, 2009, 26(3): 563-566  
Li M, Su X, Shi Z J. Memory gradient method for nonlinear equations[J]. Chinese Journal of Engineering Mathematics, 2009, 26(3): 563-566
- [4] 孙清漫, 谷亚丽, 王长钰. 一个新的带误差项的记忆梯度算法[J]. 工程数学学报, 2007, 24(5): 814-818  
Sun Q Y, Gu Y L, Wang C Y. A new memory gradient method with errors[J]. Chinese Journal of Engineering Mathematics, 2007, 24(5): 814-818
- [5] 时贞军. 非精确搜索下的超记忆梯度法[J]. 工程数学学报, 2004, 21(3): 467-470  
Shi Z J. On supermemory gradient method with inexact line searches[J]. Chinese Journal of Engineering Mathematics, 2004, 21(3): 467-470
- [6] Shi Z J. A new super-memory gradient method for unconstrained optimization[J]. Advances in Mathematics, 2006, 35(3): 265-273
- [7] 汤京永, 时贞军. 一类全局收敛的记忆梯度法及其线性收敛性[J]. 数学进展, 2007, 36(1): 67-75  
Tang J Y, Shi Z J. A class of global convergent memory gradient methods and its linear convergence rate[J]. Advances in Mathematics, 2007, 36(1): 67-75
- [8] 汤京永, 时贞军. 一类新的强 Wolfe 线性搜索下的记忆梯度法[J]. 曲阜师范大学学报, 2005, 31(2): 24-29  
Tang J Y, Shi Z J. A new class of memory gradient methods under strong Wolfe line search[J]. Journal of Qufu Normal University, 2005, 31(2): 24-29

# A New Memory Gradient Method and its Convergence

TANG Jing-yong<sup>1,2</sup>, DONG Li<sup>1</sup>

(1- College of Mathematics and Information Science, Xinyang Normal University, Xinyang 464000;  
2- Department of Mathematics, Shanghai Jiaotong University, Shanghai 200240)

**Abstract:** The memory gradient methods for unconstrained optimization problems were investigated. A new algorithm is presented which uses the current and previous one-step iterative information to generate a decent direction, and uses an Armijo linear search to determine the step-size. The new method converges globally and it has a linear convergence rate under some mild conditions. Moreover, the method avoids the computation and storage of some matrices. It is suitable for solving large scale optimization problems. Experimental results show that the new method is efficient in practical computation.

**Keywords:** unconstrained optimization; memory gradient method; global convergence; linear convergence rate

Received: 15 Aug 2008. Accepted: 17 Sep 2009.

**Foundation item:** The National Natural Science Foundation of China (10571109); the Youth Foundation of Xinyang Normal University (200946, 200947).